

The Impact of AI Knowledge, Attitudes on Technology, and Usage Experience on Student Self-Confidence (A Study at the Faculty of Business and Informatics)

Mohamad Rafii¹, Masrifah Dwi Yanti², Bayu Suratmoko³

^{1*, 1, 2}Universitas Muhammadiyah Palangkaraya, Indonesia

*Corresponding Author: mohamadrafii@gmail.com

ABSTRACT

The disruption caused by Artificial Intelligence (AI) requires psychological readiness, particularly self-confidence, among students as future professionals. This study aims to analyze and empirically test the impact of AI Knowledge (X1), Attitude on Technology (X2), and Usage Experience (X3) on students' Self-Confidence (Y). Using an explanatory quantitative approach, data were collected through an online survey of 306 students (as a sample) at the Faculty of Business and Informatics, Muhammadiyah University Palangkaraya (N=842). The data were analyzed using PLS-SEM with SmartPLS 4. The model evaluation results showed that the data were valid and reliable, with strong predictive power ($Q^2=0.620$). The bootstrapping hypothesis test results showed that all three hypotheses were accepted: AI Knowledge ($T=2.697$; $P=0.004$), Attitude on Technology ($T=5.046$; $P=0.000$), and Usage Experience ($T=5.875$; $P=0.000$) all have a positive and significant effect on Self-Confidence. These three variables collectively explain 63.3% of the variance in Self-Confidence ($R^2=0.633$). Experience of Use (X3) proved to be the most dominant predictor (coefficient=0.425; $f^2=0.195$), followed by Attitude (X2) ($f^2=0.129$), and Knowledge (X1) ($f^2=0.027$). This study concludes that to build student self-confidence, practice-based ("doing") and affective ("feeling") interventions have a much greater substantive impact than cognitive ("knowing") interventions.

Keywords: Artificial Intelligence (AI), Self-Confidence, Usage Experience, Attitude on Technology, Students.

Article history

Received:
13 December 2025

Revised:
24 December 2025

Accepted:
14 January 2026

Published:
29 January 2026

PENDAHULUAN

Perkembangan Artificial Intelligence (AI) yang eksponensial telah memicu era disrupsi teknologi yang secara fundamental mentransformasi lanskap industri global dan pasar tenaga kerja. AI tidak lagi menjadi konsep futuristik, melainkan realitas operasional yang menuntut adaptasi cepat dan perubahan paradigma dalam berbagai sektor. Tuntutan ini berdampak langsung pada kesiapan angkatan kerja masa depan, di mana mahasiswa sebagai calon profesional berada di garis depan transisi ini (Saúde et al., 2024). Secara khusus, bagi mahasiswa di Fakultas Bisnis dan Informatika, tuntutan ini bersifat ganda dan mendesak: mahasiswa Informatika diposisikan sebagai calon arsitek dan pengembang solusi AI, sementara mahasiswa Bisnis diharapkan menjadi pengguna strategis yang mampu mengintegrasikan AI untuk inovasi proses, analisis data, dan pengambilan keputusan. Kegagalan dalam merespons disrupsi ini berisiko menciptakan kesenjangan kompetensi yang signifikan, sehingga institusi pendidikan tinggi mengemban tanggung jawab vital untuk memastikan lulusannya tidak hanya kompeten secara teknis (hardskills), tetapi juga memiliki kesiapan psikologis untuk berkolaborasi dan bersaing di lingkungan profesional yang didominasi AI (Nasr et al., 2025).

Menghadapi disrupsi teknologi yang masif, kesiapan teknis saja tidak memadai; kesiapan psikologis mahasiswa menjadi faktor penentu yang sama pentingnya. Dalam konteks ini, kepercayaan diri (self-confidence) bertransisi dari sekadar sifat personal menjadi aset psikologis yang dinamis dan krusial. Kepercayaan diri berfungsi sebagai moderator internal yang memengaruhi cara mahasiswa memandang, mendekati, dan merespons kompleksitas serta ketidakpastian yang dibawa oleh AI (Kim & Lee, 2024). Literatur psikologi secara konsisten menunjukkan bahwa individu dengan kepercayaan diri yang tinggi cenderung lebih proaktif dalam mengambil inisiatif, memiliki kegigihan (persistence) yang lebih baik dalam menghadapi tantangan, dan lebih adaptif dalam memecahkan masalah kompleks—keterampilan yang esensial untuk unggul di era AI (Marzilli et al., 2022). Sebaliknya, rendahnya kepercayaan diri dapat bermanifestasi sebagai kecemasan teknologi (techno-anxiety) atau resistensi, yang secara langsung menghambat proses adaptasi dan pembelajaran. Oleh karena itu, mengidentifikasi anteseden yang membentuk kepercayaan diri mahasiswa Bisnis dan Informatika terhadap AI menjadi sebuah urgensi penelitian yang fundamental (Janson, 2023).

Meskipun urgensi kesiapan psikologis telah teridentifikasi, literatur ilmiah masih menunjukkan kesenjangan (research gap) yang signifikan dalam memahami determinan spesifik dari kepercayaan diri mahasiswa di era AI. Kepercayaan diri tidak terbentuk dalam ruang hampa; ia merupakan hasil dari interaksi kompleks antara faktor kognitif, afektif, dan pengalaman (Linge et al., 2021). Penelitian ini berargumen bahwa dalam konteks disrupsi teknologi, tiga anteseden utama adalah: Pengetahuan AI (X1) sebagai komponen kognitif, Sikap terhadap Teknologi (X2) sebagai komponen afektif, dan Pengalaman Penggunaan (X3) sebagai komponen perilaku/konatif. Studi-studi sebelumnya cenderung mengeksplorasi variabel-variabel ini secara terisolasi atau dalam konteks yang berbeda, seperti adopsi teknologi (misalnya, dalam model TAM atau UTAUT) yang berfokus pada 'niat penggunaan' (intention to use). Namun, masih sangat terbatas penelitian empiris yang menguji sebuah model integratif untuk memprediksi bagaimana ketiga faktor ini secara simultan berkontribusi pada pembentukan Kepercayaan Diri (sebagai variabel hasil psikologis) secara spesifik di kalangan mahasiswa.

Mengisi kesenjangan penelitian ini menjadi krusial, khususnya dalam konteks lokal penelitian ini di Universitas Muhammadiyah Palangkaraya, yang memiliki peran strategis dalam mencetak talenta bisnis dan informatika di Kalimantan. Memahami kesiapan psikologis mahasiswa di lingkungan ini adalah langkah fundamental. Oleh karena itu, penelitian ini bertujuan secara spesifik untuk menganalisis dan menguji secara empiris pengaruh Pengetahuan AI (X1), Sikap terhadap Teknologi (X2), dan Pengalaman Penggunaan (X3) terhadap Kepercayaan Diri (Y) mahasiswa di Fakultas Bisnis dan Informatika. Diharapkan, penelitian ini dapat memberikan kontribusi ganda: secara teoretis, [penelitian ini] akan memvalidasi sebuah model integratif anteseden psikologis kepercayaan diri di era AI; dan secara praktis, temuan ini dapat memberikan landasan berbasis data bagi fakultas untuk merancang intervensi kurikuler dan program pengembangan yang efektif guna memperkuat kepercayaan diri mahasiswa dalam menghadapi disrupsi teknologi.

METODOLOGI

Penelitian ini mengadopsi pendekatan kuantitatif dengan menggunakan desain penelitian eksplanatori (explanatory research). Desain ini dipilih karena tujuan utama penelitian adalah untuk menguji hipotesis yang telah dirumuskan dan menganalisis hubungan sebab-akibat, secara spesifik menjelaskan "dampak" atau pengaruh variabel independen (Pengetahuan AI, Sikap terhadap Teknologi, dan Pengalaman Penggunaan) terhadap variabel dependen (Kepercayaan Diri Mahasiswa). Untuk memperoleh data primer yang diperlukan guna menguji hubungan kausal tersebut, penelitian ini menerapkan metode survei dengan kuesioner terstruktur sebagai instrumen pengumpulan data utama.

Populasi (N) dalam penelitian ini adalah seluruh mahasiswa aktif Fakultas Bisnis dan Informatika, Universitas Muhammadiyah Palangkaraya pada tahun 2025, yang berjumlah 842 mahasiswa. Untuk menentukan ukuran sampel (n) yang representatif, digunakan rumus Slovin dengan tingkat presisi (margin of error) 5% (Shaikat et al., 2022), sehingga diperoleh ukuran

sampel minimum 271 responden. Namun, untuk meningkatkan kekuatan statistik dan mengantisipasi drop out kuesioner, penelitian ini menetapkan jumlah target sampel yang lebih besar, yaitu sebanyak 306 mahasiswa. Teknik pengambilan sampel yang digunakan adalah proportional stratified random sampling, di mana populasi dibagi terlebih dahulu berdasarkan strata program studi (Bisnis dan Informatika) untuk memastikan keterwakilan proporsional dari kedua kelompok tersebut dalam sampel akhir.

Penelitian ini mengukur empat variabel laten utama, yang terdiri dari tiga variabel independen dan satu variabel dependen. Variabel independen pertama adalah Pengetahuan AI (X1), yang didefinisikan secara operasional sebagai tingkat pemahaman kognitif mahasiswa Fakultas Bisnis dan Informatika mengenai konsep, terminologi, dan aplikasi dasar AI. Variabel kedua adalah Sikap terhadap Teknologi (X2), yang diukur sebagai evaluasi afektif (perasaan positif atau negatif) dan kecenderungan perilaku mahasiswa terhadap penggunaan dan adopsi teknologi baru. Variabel ketiga, Pengalaman Penggunaan (X3), didefinisikan sebagai frekuensi, durasi, dan keragaman interaksi aktual mahasiswa dengan berbagai alat atau platform berbasis AI. Variabel dependen adalah Kepercayaan Diri (Y), yang didefinisikan secara operasional sebagai keyakinan subjektif mahasiswa atas kemampuan mereka untuk memahami, menggunakan, dan beradaptasi secara efektif dengan tuntutan teknologi AI. Seluruh konstruk ini diukur menggunakan item-item indikator yang diadaptasi dari instrumen penelitian sebelumnya [Sebutkan Peneliti, Tahun], dan setiap item diukur menggunakan skala Likert 5 poin, dengan rentang dari 1 (Sangat Tidak Setuju) hingga 5 (Sangat Setuju).

Teknik pengumpulan data primer dalam penelitian ini dilakukan melalui penyebaran kuesioner survei secara daring (misalnya, menggunakan Google Forms) kepada 306 responden yang telah ditetapkan. Data mentah yang terkumpul kemudian dianalisis menggunakan pendekatan Structural Equation Modeling (SEM) berbasis komponen, yaitu Partial Least Squares (PLS-SEM). Pemilihan PLS-SEM sebagai alat analisis utama didasarkan pada beberapa justifikasi: (1) tujuan penelitian ini bersifat prediktif, sejalan dengan kekuatan utama PLS-SEM; (2) model penelitian ini bersifat kompleks dan dikembangkan secara teoretis; dan (3) PLS-SEM tidak memerlukan asumsi distribusi normalitas data yang ketat, sehingga lebih robust untuk data ilmu sosial (Pereira et al., 2024). Seluruh proses analisis data, mulai dari evaluasi model pengukuran hingga pengujian hipotesis model struktural, dilakukan dengan bantuan perangkat lunak SmartPLS versi 4.

Prosedur analisis data PLS-SEM dalam penelitian ini akan dilakukan melalui dua tahapan evaluasi yang sistematis menggunakan SmartPLS 4. Tahap pertama adalah evaluasi model pengukuran (outer model) untuk memastikan validitas dan reliabilitas instrumen. Evaluasi ini mencakup: (a) Uji Validitas Konvergen, dengan memeriksa nilai Outer Loadings (> 0.70) dan Average Variance Extracted (AVE) (> 0.50); (b) Uji Validitas Diskriminan, dengan menggunakan Kriteria Fornell-Larcker dan/atau Heterotrait-Monotrait Ratio (HTMT) (< 0.90); dan (c) Uji Reliabilitas Konstruk, dengan menilai nilai Cronbach's Alpha dan Composite Reliability (CR) (> 0.70). Setelah model pengukuran terkonfirmasi valid dan reliabel, analisis dilanjutkan ke tahap kedua, yaitu evaluasi model struktural (inner model). Tahap ini berfokus pada pengujian hipotesis dan penilaian kekuatan prediktif model, yang meliputi: (a) Penilaian R-Square (R^2) untuk variabel dependen; (b) Penilaian Effect Size (f^2); (c) Uji relevansi prediktif (Q^2 Stone-Geisser); dan (d) Uji signifikansi hipotesis melalui prosedur Bootstrapping untuk memperoleh nilai T-Statistics dan P-Values (Hair et al., 2019).

HIPOTESIS

Hipotesis ini didasarkan pada asumsi bahwa kepercayaan diri (sebagai bentuk self-efficacy) dibangun melalui tiga pilar: apa yang kita tahu (kognitif), apa yang kita rasakan (afektif), dan apa yang kita lakukan (pengalaman).

Berikut adalah kerangka hipotesis untuk penelitian ini:

H1: Pengaruh Pengetahuan AI terhadap Kepercayaan Diri

Secara teoretis, pengetahuan berfungsi sebagai fondasi kognitif untuk kepercayaan diri. Semakin tinggi tingkat pemahaman (Pengetahuan) seorang mahasiswa mengenai apa itu AI,

bagaimana cara kerjanya, serta apa kapabilitas dan keterbatasannya, semakin rendah tingkat ketidakpastian (uncertainty) dan kecemasan (anxiety) yang mereka rasakan. Pengetahuan yang memadai mengubah AI dari "kotak hitam" yang mengintimidasi menjadi alat yang dapat dipahami dan dikelola (Ocak et al., 2023). Oleh karena itu, hipotesis pertama dirumuskan:

H1: Pengetahuan AI (X1) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa.

H2: Pengaruh Sikap terhadap Teknologi terhadap Kepercayaan Diri

Sikap merepresentasikan komponen afektif. Mahasiswa yang memiliki sikap positif terhadap teknologi (X2)—memandangnya sebagai fasilitator yang berguna dan menarik, bukan sebagai ancaman—cenderung lebih terbuka (open) dan optimis. Sikap positif ini akan mendorong kemauan untuk belajar dan berinteraksi dengan teknologi baru, yang pada gilirannya akan membangun keyakinan (belief) pada kemampuan mereka sendiri untuk beradaptasi. Sebaliknya, sikap negatif (teknofobia) akan menciptakan hambatan psikologis yang meruntuhkan kepercayaan diri (Herce et al., 2024). Oleh karena itu, hipotesis kedua dirumuskan:

H2: Sikap terhadap Teknologi (X2) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa.

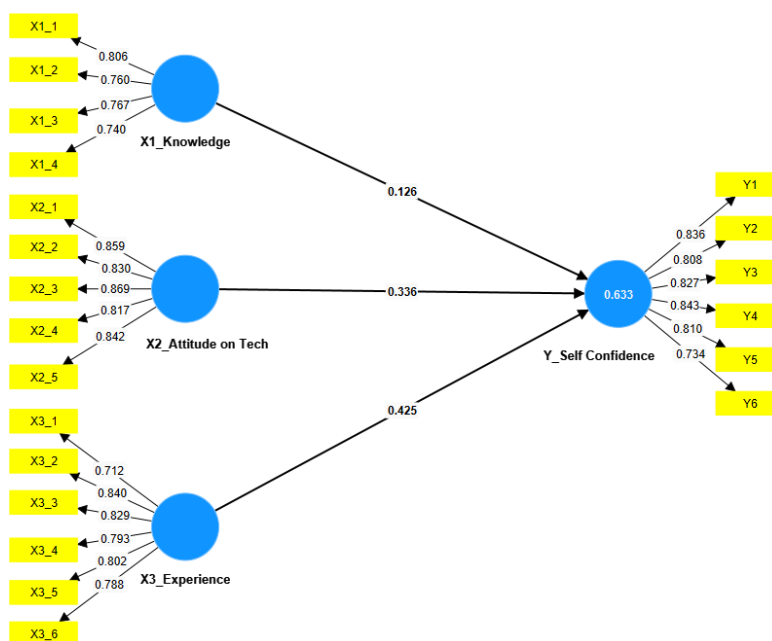
H3: Pengaruh Pengalaman Penggunaan terhadap Kepercayaan Diri

Ini adalah hipotesis yang didasarkan pada Teori Self-Efficacy Bandura, di mana "pengalaman penguasaan" (mastery experiences) adalah sumber pembentuk kepercayaan diri yang paling kuat. Semakin sering mahasiswa secara nyata berinteraksi dan menggunakan (Pengalaman) alat-alat berbasis AI (X3)—baik dalam tugas kuliah maupun aktivitas pribadi—mereka akan mendapatkan bukti empiris langsung atas kemampuan mereka. Setiap keberhasilan kecil dalam menggunakan AI akan membangun keyakinan bahwa "Saya bisa melakukan ini," yang secara langsung meningkatkan kepercayaan diri mereka (Linge et al., 2021). Oleh karena itu, hipotesis ketiga dirumuskan:

H3: Pengalaman Penggunaan (X3) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa.

MODEL PENELITIAN

Model yang digunakan dalam penelitian ini adalah:



Gambar 1. Model Penelitian

ANALISA DATA

ANALISA OUTER MODEL / CONFIRMATORY FACTOR ANALYSIS (CFA)

Penilaian outer model (model pengukuran) adalah fondasi dalam analisis PLS-SEM, yang dirancang untuk memvalidasi dan memastikan keandalan konstruk penelitian. Berpedoman pada (9), evaluasi ini memeriksa reliabilitas konstruk melalui Cronbach's Alpha dan Composite Reliability (CR) untuk mengukur konsistensi internal. Selain itu, model ini juga menguji validitas dalam dua aspek: validitas konvergen dan validitas diskriminan. Validitas konvergen (dibuktikan dengan loading factor > 0.70 dan AVE > 0.50) menegaskan bahwa indikator-indikator berkorelasi tinggi dengan konstruknya. Sementara itu, validitas diskriminan (diuji via Fornell-Larcker Criterion dan Cross Loading) mengkonfirmasi bahwa setiap konstruk adalah entitas yang berbeda dan tidak tumpang tindih dengan konstruk lainnya (Saulite & Ščeuļovs, 2022).

Esensi dari pengujian outer model dalam penelitian sosial adalah untuk menjamin kualitas alat ukur sebelum menarik kesimpulan apapun. Sederhananya, hasil inner model tidak dapat dipercaya jika outer model-nya bermasalah (Khan et al., 2021). Kualitas ini dibuktikan secara statistik: nilai loading factor, AVE, dan CR yang tinggi menandakan bahwa indikator yang kita gunakan memang tepat dan konsisten dalam mengukur variabel laten. Sejalan dengan Hamid dan Anwar (2019), model pengukuran yang teruji baik akan menghasilkan estimasi struktural yang stabil dan bebas dari masalah teknis seperti multikolinearitas (Kratzer et al., 2021). Karena itu, mengevaluasi outer model bukanlah sekadar formalitas, melainkan langkah kritis fundamental untuk memastikan validitas kesimpulan penelitian sebelum beranjak ke analisis model fit atau pengujian hubungan struktural (Kawaguchi et al., 2021).

1. Uji Validitas Konvergen

a. Loading Factor

Validitas konvergen bertujuan untuk mengkonfirmasi bahwa sekelompok indikator memang berkumpul untuk mengukur satu konstruk laten yang sama. Dalam praktik PLS-SEM, konfirmasi ini diperoleh dengan mengevaluasi nilai loading factor. Analisis ini adalah langkah penyaringan awal yang penting untuk memastikan ketepatan hubungan indikator-konstruk (Salata & Yiannakou, 2023). Sebuah indikator dianggap valid jika loading factor-nya melampaui 0,70 (menandakan lebih dari 50% varians dijelaskan oleh konstruk). Jika tidak, peneliti dihadapkan pada keputusan: indikator tersebut umumnya harus dieliminasi, kecuali jika kehadirannya dianggap krusial secara teoretis dan model pengukuran konstruk tersebut tetap reliabel serta mencapai AVE di atas 0,50 (García-Machado et al., 2021).

Tabel 1. Loading Factor dalam Uji Validitas Konvergen

Instrumen	X1_ Knowledge	X2_ Attitude on Tech	X3_ Experience	Y_ Self Confidence	Keterangan
X1_1	0.806				Valid
X1_2	0.760				Valid
X1_3	0.767				Valid
X1_4	0.740				Valid
X2_1		0.859			Valid
X2_2		0.830			Valid
X2_3		0.869			Valid
X2_4		0.817			Valid
X2_5		0.842			Valid
X3_1			0.712		Valid
X3_2			0.840		Valid
X3_3			0.829		Valid

X3_4	0.793	Valid
X3_5	0.802	Valid
X3_6	0.788	Valid
Y1	0.836	Valid
Y2	0.808	Valid
Y3	0.827	Valid
Y4	0.843	Valid
Y5	0.810	Valid
Y6	0.734	Valid

Sumber: Disusun oleh penulis, 2025

Dalam metodologi PLS-SEM, validitas konvergen menilai apakah item-item (indikator) memang secara akurat mengukur variabel laten (konstruk) yang diwakilinya. Tolak ukur utama untuk ini adalah loading factor. Standar ideal untuk loading factor adalah $> 0,70$ (Yang et al., 2023). Namun, metodologi ini memberikan fleksibilitas: loading factor yang lebih rendah, spesifiknya antara 0,60 hingga 0,70, masih dapat dipertimbangkan (diterima) asalkan konstruk tersebut tetap menunjukkan reliabilitas internal (Composite Reliability) yang baik dan nilai Average Variance Extracted (AVE) di atas 0,50 (Zhou & Liu, 2022).

Pengujian validitas konvergen dilakukan untuk menilai sejauh mana setiap indikator (item) mampu merepresentasikan konstruk laten (variabel) yang diukurnya. Dalam analisis PLS-SEM, kriteria utama yang digunakan adalah nilai outer loading (loading factor), di mana nilai yang direkomendasikan harus lebih besar dari 0,70 (Afnisah et al., 2025). Berdasarkan hasil analisis data, seluruh 21 indikator yang digunakan dalam penelitian ini menunjukkan nilai loading factor yang sangat baik dan melampaui ambang batas 0,70.

Secara rinci, nilai loading untuk konstruk X1_Knowledge berkisar antara 0,740 hingga 0,806. Konstruk X2_Attitude on Tech memiliki nilai loading antara 0,817 hingga 0,869. Konstruk X3_Experience menunjukkan nilai loading antara 0,712 hingga 0,840. Terakhir, konstruk Y_Self Confidence memiliki nilai loading antara 0,734 hingga 0,843. Dengan nilai loading terendah adalah 0,712 (pada item X3_1), yang masih berada jauh di atas standar minimal, maka dapat disimpulkan bahwa semua indikator dinyatakan valid secara konvergen dan tidak ada indikator yang perlu dieliminasi dari model.

b. Average Variance Extracted (AVE)

Sebagai pelengkap loading factor, Average Variance Extracted (AVE) digunakan untuk menilai validitas konvergen pada level agregat (konstruk). AVE pada dasarnya adalah uji diagnostik untuk menentukan apakah suatu konstruk mampu menjelaskan varians indikator-indikatornya dengan baik. Semakin tinggi nilai AVE, semakin tinggi tingkat konsistensi representasi indikator terhadap konstruk tersebut (Wang & Zhao, 2023). Sebuah konstruk harus memiliki nilai $AVE \geq 0,50$ agar dianggap valid secara konvergen. Jika syarat minimal 50% varians dijelaskan ini tidak terpenuhi, maka konstruk tersebut memiliki masalah validitas, dan peneliti harus meninjau ulang model pengukuran, misalnya dengan menghapus indikator yang berkontribusi lemah (Chavarría-Arroyo & Albanese, 2023).

Tabel 2. Hasil Average Variance Extracted (AVE) dalam Uji Validitas Konvergen

Instrumen	Average variance extracted (AVE)	Keterangan
X1_Knowledge	0.591	Valid
X2_Attitude on Tech	0.712	Valid
X3_Experience	0.632	Valid
Y_Self Confidence	0.657	Valid

Sumber: Disusun oleh penulis, 2025

Uji validitas konvergen juga dinilai berdasarkan nilai Average Variance Extracted (AVE) untuk setiap konstruk. Kriteria yang ditetapkan adalah nilai AVE harus $\geq 0,50$ (Hair et al., 2019). Tabel 2 menunjukkan bahwa semua konstruk penelitian memenuhi kriteria tersebut. Konstruk X1_Knowledge memiliki nilai AVE 0.591, X2_Attitude on Tech 0.712, X3_Experience 0.632, dan Y_Self Confidence 0.657. Karena seluruh nilai AVE secara signifikan berada di atas ambang batas 0,50, maka dapat disimpulkan bahwa model pengukuran ini memiliki validitas konvergen yang baik pada level konstruk.

2. Uji Validitas Diskriminan

a. Cross Loading

Tujuan utama dari uji validitas diskriminan adalah untuk menunjukkan adanya tingkat separasi (pemisahan) yang memadai antar variabel laten. Metode Cross Loading adalah salah satu cara untuk mendemonstrasikan separasi ini. Logikanya, setiap indikator harus berkontribusi paling besar hanya pada satu konstruk laten (Yu & Chang, 2025). Kriteria terpenuhi ketika nilai loading sebuah indikator pada konstruk targetnya melampaui nilai loading indikator tersebut ke konstruk-konstruk lainnya. Jika loading sebuah indikator terbagi atau bahkan lebih tinggi pada konstruk lain, hal ini menandakan masalah validitas diskriminan (konstruk tumpang tindih). Tingkat diskriminasi yang baik terkonfirmasi ketika selisih antara loading pada konstruk asal dan loading pada konstruk lain terlihat jelas (Tambunan et al., 2024).

Tabel 3. Hasil Cross Loading pada Uji Validitas Diskriminan

Pernyataan	X1_Knowledge	X2_Attitude on Tech	X3_Experience	Y_Self Confidence	Keterangan
X1 1	0.806	0.476	0.447	0.423	Valid
X1 2	0.760	0.372	0.379	0.378	Valid
X1 3	0.767	0.450	0.426	0.404	Valid
X1 4	0.740	0.404	0.536	0.503	Valid
X2 1	0.487	0.859	0.600	0.583	Valid
X2 2	0.512	0.830	0.679	0.648	Valid
X2 3	0.391	0.869	0.603	0.587	Valid
X2 4	0.521	0.817	0.602	0.609	Valid
X2 5	0.423	0.842	0.662	0.618	Valid
X3 1	0.355	0.647	0.712	0.589	Valid
X3 2	0.417	0.613	0.840	0.628	Valid
X3 3	0.495	0.572	0.829	0.637	Valid
X3 4	0.518	0.541	0.793	0.589	Valid
X3 5	0.521	0.609	0.802	0.589	Valid
X3 6	0.517	0.586	0.788	0.540	Valid
Y1	0.437	0.652	0.584	0.836	Valid
Y2	0.469	0.549	0.578	0.808	Valid
Y3	0.415	0.615	0.579	0.827	Valid
Y4	0.430	0.566	0.576	0.843	Valid
Y5	0.514	0.606	0.676	0.810	Valid
Y6	0.467	0.523	0.645	0.734	Valid

Sumber: Disusun oleh penulis, 2025

Uji validitas diskriminan juga dievaluasi melalui kriteria cross loading. Tabel 3 menyajikan matriks cross loading dari semua indikator terhadap semua konstruk. Validitas diskriminan terpenuhi apabila nilai loading setiap indikator pada konstruk asalnya (ditunjukkan dengan nilai tebal) lebih tinggi dibandingkan dengan nilai cross loading indikator tersebut ke konstruk lainnya. Hasil analisis menunjukkan bahwa seluruh 21 indikator memiliki nilai loading tertinggi pada konstruk induknya masing-

masing. Sebagai contoh, indikator X1_1 memiliki loading 0.806 pada konstruk X1_Knowledge, yang lebih tinggi dari loading-nya ke konstruk X2 (0.476), X3 (0.447), dan Y (0.423). Pola yang sama terkonfirmasi untuk semua indikator lainnya, sehingga dapat disimpulkan bahwa model ini memiliki validitas diskriminan yang baik pada level indikator.

b. Fornell-Larcker

Metode Fornell-Larcker (1981) adalah pendekatan prosedural untuk memvalidasi bahwa setiap konstruk bersifat unik dan tidak tumpang tindih. Dalam praktiknya, metode ini membandingkan akar kuadrat Average Variance Extracted (\sqrt{AVE}) dengan matriks korelasi antar konstruk. Sebuah konstruk dianggap memiliki validitas diskriminan yang baik hanya jika nilai \sqrt{AVE} -nya (yang sering ditempatkan di diagonal tabel) lebih besar daripada koefisien korelasi di kolom dan barisnya (nilai off-diagonal). Pemenuhan syarat ini menunjukkan bahwa varians yang dijelaskan konstruk dari item-itemnya sendiri lebih dominan daripada varians yang ia bagi dengan konstruk lain (Hilkenmeier et al., 2020).

Tabel 4. Hasil Discriminant Validity - Fornell Larcker Criterion

Variabel	X1_Knowledge	X2_Attitude on Tech	X3_Experience	Y_Self Confidence	Keterangan
X1_Knowledge	0.769				Valid
X2_Attitude on Tech	0.555	0.844			Valid
X3_Experience	0.590	0.748	0.795		Valid
Y_Self Confidence	0.564	0.724	0.751	0.810	Valid

Sumber: Disusun oleh penulis, 2025

Uji validitas diskriminan dilakukan dengan menggunakan Kriteria Fornell-Larcker (1981), yang membandingkan nilai akar kuadrat dari Average Variance Extracted (\sqrt{AVE}) setiap konstruk (nilai di diagonal) dengan koefisien korelasi antar konstruk (nilai di luar diagonal). Sebuah konstruk dinyatakan memiliki validitas diskriminan yang baik apabila nilai \sqrt{AVE} -nya lebih tinggi daripada nilai korelasinya dengan semua konstruk lain (Rasoolimanesh, 2022).

Tabel 4 menunjukkan bahwa semua konstruk memenuhi kriteria ini. Konstruk X1_Knowledge memiliki \sqrt{AVE} sebesar 0.769, yang lebih tinggi dari korelasinya dengan X2 (0.555), X3 (0.590), dan Y (0.564). Pola yang sama terkonfirmasi untuk semua konstruk lainnya: X2 ($\sqrt{AVE} = 0.844$), X3 ($\sqrt{AVE} = 0.795$), dan Y ($\sqrt{AVE} = 0.810$), yang semuanya lebih besar dari korelasi off-diagonal di baris dan kolom masing-masing. Dengan demikian, dapat disimpulkan bahwa model ini memiliki validitas diskriminan yang kuat pada level konstruk (Kusuma & Rachmawati, 2024).

3. Uji Reabilitas

a. Cronbach's Alpha

Cronbach's Alpha adalah salah satu metrik utama dalam uji reliabilitas yang dirancang untuk menilai stabilitas instrumen dan konsistensi internal antar indikator. Metrik ini menunjukkan apakah semua item pertanyaan secara reliabel mengukur konsep (variabel laten) yang sama. Sebuah konstruk dianggap reliabel jika nilai Cronbach's Alpha-nya $\geq 0,70$. Meskipun demikian, dalam konteks penelitian eksploratori, standar yang sedikit lebih longgar (antara 0,60–0,70) seringkali masih dianggap cukup. Semakin tinggi nilainya, semakin kuat bukti bahwa indikator-indikator tersebut stabil dan konsisten (Zakariya, 2022).

Tabel 5. Hasil Cronbach's Alpha dalam Uji Reliabilitas

Variabel	Cronbach's alpha	Keterangan
X1_Knowledge	0.770	Reliabel

X2 Attitude on Tech	0.899	Reliabel
X3 Experience	0.883	Reliabel
Y Self Confidence	0.895	Reliabel

Sumber: Disusun oleh penulis, 2025

Hasil analisis (Tabel 5) menunjukkan bahwa keempat konstruk penelitian memenuhi syarat reliabilitas. Konstruk X1_Knowledge memiliki nilai Alpha 0.770. Sementara itu, tiga konstruk lainnya menunjukkan reliabilitas yang sangat baik: X2_Attitude on Tech (0.899), X3_Experience (0.883), dan Y_Self Confidence (0.895). Karena semua nilai Cronbach's Alpha berada di atas ambang batas 0.70, dapat disimpulkan bahwa seluruh instrumen yang digunakan dalam penelitian ini adalah reliabel.

b. Composite Reliability

Parameter reliabilitas kedua yang dievaluasi adalah Composite Reliability (CR), yang memberikan ukuran konsistensi internal yang lebih baik dalam konteks PLS-SEM. Tidak seperti Cronbach's Alpha (yang merupakan lower bound reliabilitas), CR tidak mengasumsikan loading yang setara, melainkan menggunakan kontribusi aktual indikator untuk menghitung reliabilitas. Oleh karena itu, CR dianggap lebih akurat. Nilai $\geq 0,70$ diterima sebagai reliabel, $\geq 0,60$ dapat dipertimbangkan untuk studi eksploratori, dan nilai di atas 0,90 mencerminkan konsistensi internal yang sangat tinggi (Demir & Uşak, 2025).

Tabel 6. Composite Reliability dalam Uji Reliabilitas

Variabel	Composite reliability (rho c)	Keterangan
X1 Knowledge	0.852	Reliabel
X2 Attitude on Tech	0.925	Reliabel
X3 Experience	0.911	Reliabel
Y Self Confidence	0.920	Reliabel

Sumber: Disusun oleh penulis, 2025

Pengujian reliabilitas konstruk juga dikonfirmasi menggunakan nilai Composite Reliability (CR) atau rho_c. Composite Reliability dianggap sebagai ukuran yang lebih akurat dalam PLS-SEM karena memperhitungkan kontribusi aktual setiap indikator. Sama seperti Cronbach's Alpha, kriteria yang digunakan adalah $\geq 0,70$.

Hasil analisis (Tabel 6) menunjukkan bahwa semua konstruk memiliki reliabilitas yang sangat kuat. Konstruk X1_Knowledge memiliki nilai CR 0.852. Tiga konstruk lainnya menunjukkan reliabilitas yang sangat tinggi: X2_Attitude on Tech (0.925), X3_Experience (0.911), dan Y_Self Confidence (0.920). Karena semua nilai CR jauh di atas ambang batas 0.70, dapat disimpulkan bahwa model pengukuran ini memiliki konsistensi internal yang sangat baik.

UJI MODEL FIT

Evaluasi model fit dalam PLS-SEM krusial untuk menentukan apakah model struktural yang dihipotesiskan konsisten dengan data empiris. Kecocokan model dinilai menggunakan beberapa indikator. Tolok ukur utama adalah Standardized Root Mean Square Residual (SRMR), yang idealnya harus di bawah 0.10. Selain itu, model dianggap fit jika discrepancy measures seperti d_ULS dan d_G menunjukkan nilai signifikansi $p > 0.05$, yang mengindikasikan bahwa perbedaan antara matriks kovarians yang diestimasi dan yang diamati tidak signifikan. Metrik lain seperti Normed Fit Index (NFI) yang mendekati 1 dan nilai Chi-Square hitung yang lebih rendah dari Chi-Square tabel juga

digunakan untuk memperkuat kesimpulan bahwa model tersebut sesuai dengan data (Kock, 2020).

Tabel 7. Hasil Model Fit

Parameter	Rule of Thumb	Hasil Perhitungan	Keterangan
SRMR (Standardized Root Mean Square Residual)	$SRMR < 0.10 \rightarrow$ Model fit	0.071	Fit
d_ ULS (Squared Euclidean Distance)	$p\text{-value} > 0.05 \rightarrow$ Model fit	1.155	Fit
d_ G (Geodesic Distance)	$p\text{-value} > 0.05 \rightarrow$ Model fit	0.468	Fit
Chi-Square (χ^2)	$\chi^2 \text{ hitung} \leq \chi^2 \text{ tabel (df = 20; } \alpha = 0.05 \rightarrow \chi^2 \text{ tabel = 31.410)}$	$832.253 > 31.410$	Tidak Fit
NFI (Normed Fit Index)	Nilai NFI mendekati 1 (≥ 0.90 ideal)	0.808	Fit
Goodness of Fit (GoF)	$0.10 = \text{GoF kecil} \cdot 0.25 = \text{GoF moderat} \cdot 0.36 = \text{GoF besar} \rightarrow$ Semakin besar nilainya, semakin baik model	0.657	Fit
Q ² Predictive Relevance (Stone-Geisser's Q ²)	$Q^2 > 0 \rightarrow$ Model memiliki predictive relevance • $0.02 = \text{lemah} \cdot 0.15 = \text{moderat} \cdot 0.35 = \text{kuat}$	0.620	Fit

Sumber: Disusun oleh penulis, 2025

1. Hasil Uji Standardized Root Mean Square Residual (SRMR)

Penilaian kecocokan model (model fit) salah satunya dilakukan dengan mengevaluasi nilai Standardized Root Mean Square Residual (SRMR). SRMR berfungsi untuk mengukur perbedaan rata-rata (residual) antara korelasi yang diamati (data empiris) dan korelasi yang diprediksi oleh model. Sesuai dengan rule of thumb yang umum digunakan (misalnya Hair et al., 2019), sebuah model dianggap memiliki kecocokan yang baik apabila nilai SRMR berada di bawah 0.10. Hasil perhitungan dari analisis ini menunjukkan nilai SRMR sebesar 0.071. Oleh karena nilai 0.071 tersebut lebih rendah dari ambang batas 0.10, maka dapat disimpulkan bahwa model penelitian ini telah Fit atau sesuai dengan data.

2. Hasil Uji d_ ULS (Squared Euclidean Distance)

Kecocokan model juga dinilai menggunakan d_ ULS (Squared Euclidean Distance), yang merupakan salah satu ukuran discrepancy untuk menilai perbedaan (jarak) antara matriks kovarians yang dihasilkan model dan matriks kovarians data empiris. Sesuai dengan rule of thumb, model dianggap fit apabila perbedaan ini tidak signifikan secara statistik, yang ditunjukkan dengan nilai $p\text{-value} > 0.05$. Hasil perhitungan menunjukkan nilai statistik d_ ULS adalah 1.155. Sebagaimana disajikan pada Tabel 7, hasil ini dinyatakan 'Fit', yang mengindikasikan bahwa nilai $p\text{-value}$ yang terkait (meskipun tidak ditampilkan) lebih besar dari 0.05. Dengan demikian, dapat disimpulkan bahwa tidak terdapat perbedaan yang signifikan antara model dan data, dan model ini dapat diterima berdasarkan kriteria d_ ULS.

3. Hasil Uji d_ G (Geodesic Distance)

Kecocokan model juga dinilai menggunakan d_ G (Geodesic Distance). Serupa dengan d_ ULS, parameter ini berfungsi sebagai ukuran discrepancy yang menilai jarak (perbedaan) antara matriks kovarians yang diestimasi oleh model dan matriks kovarians data empiris. Kriteria penerimaannya adalah model dianggap 'Fit' apabila perbedaan tersebut tidak signifikan secara statistik, yang ditunjukkan oleh nilai $p\text{-value} > 0.05$. Hasil perhitungan (Tabel 7) menunjukkan nilai statistik d_ G adalah 0.468. Karena tabel menyimpulkan hasil ini sebagai 'Fit', ini mengindikasikan bahwa $p\text{-value}$ yang terkait lebih besar dari 0.05.

Dengan demikian, model penelitian ini dianggap sesuai dengan data empiris berdasarkan kriteria Geodesic Distance.

4. Hasil Uji Chi-Square (X^2)

Uji kecocokan model selanjutnya adalah Chi-Square (X^2). Berdasarkan rule of thumb, sebuah model dianggap fit apabila nilai X^2 hitung (calculated) lebih kecil atau sama dengan (\leq) nilai X^2 tabel pada degrees of freedom (df) dan tingkat α tertentu. Hasil analisis (Tabel 7) menunjukkan nilai X^2 hitung sebesar 832.253, sementara nilai X^2 tabel (untuk df=20 dan $\alpha=0.05$) adalah 31.410. Karena nilai X^2 hitung (832.253) secara signifikan lebih besar daripada nilai X^2 tabel (31.410), maka model ini dinyatakan "Tidak Fit" berdasarkan kriteria Chi-Square.

Dalam metodologi PLS-SEM, parameter Chi-Square sangat sensitif terhadap jumlah sampel dan kompleksitas model. Sangat umum (dan sering diharapkan) bahwa model akan menunjukkan "Tidak Fit" pada parameter ini, terutama jika jumlah sampel besar. Oleh karena itu, dalam praktik PLS-SEM, peneliti lebih disarankan untuk mengandalkan parameter fit lainnya seperti SRMR dan NFI. Dalam kasus Anda, SRMR (0.071) dan NFI (0.808) keduanya menunjukkan hasil "Fit", yang memberikan justifikasi kuat bahwa model Anda secara keseluruhan tetap baik dan dapat diterima.

5. Hasil Uji Normed Fit Index (NFI)

Parameter kecocokan model selanjutnya adalah Normed Fit Index (NFI). NFI merupakan ukuran incremental fit yang menilai seberapa baik model yang diusulkan (model Anda) dibandingkan dengan null model (model dasar tanpa hubungan). Sesuai dengan rule of thumb, nilai NFI yang ideal adalah mendekati 1, seringkali dengan ambang batas yang direkomendasikan ≥ 0.90 untuk fit yang baik.

Hasil perhitungan (Tabel 7) menunjukkan nilai NFI untuk model ini adalah 0.808. Meskipun nilai ini berada sedikit di bawah kriteria ideal 0.90, nilai di atas 0.80 sering dianggap sebagai kecocokan yang dapat diterima (acceptable fit) dalam banyak penelitian. Oleh karena itu, sebagaimana dinyatakan dalam kolom 'Keterangan', model ini diklasifikasikan sebagai 'Fit'. Ini mengindikasikan bahwa model penelitian Anda 80.8% lebih baik dalam menjelaskan data dibandingkan dengan null model, yang menunjukkan kecocokan yang memadai.

6. Hasil Goodness of Fit (GoF)

Parameter Goodness of Fit (GoF) digunakan untuk menilai kecocokan model secara keseluruhan, yang mempertimbangkan performa model pengukuran (outer model) dan model struktural (inner model). Berdasarkan rule of thumb yang disajikan, nilai GoF dapat dikategorikan sebagai kecil (0.10), moderat (0.25), atau besar (≥ 0.36), di mana nilai yang lebih besar menunjukkan kecocokan model yang lebih baik. Hasil perhitungan (Tabel 7) menunjukkan nilai GoF untuk model ini adalah 0.657. Oleh karena nilai 0.657 ini secara signifikan berada di atas ambang batas untuk 'GoF besar' (0.36), maka dapat disimpulkan bahwa model penelitian ini memiliki tingkat kecocokan keseluruhan yang sangat baik dan dinyatakan 'Fit'.

7. Hasil Uji Q^2 Predictive Relevance (Stone-Geisser's Q^2)

Uji Q^2 Predictive Relevance (juga dikenal sebagai Stone-Geisser's Q^2) dilakukan untuk menilai kemampuan prediktif dari model struktural, yaitu seberapa baik model tersebut dapat memprediksi kembali data observasi aslinya. Sesuai dengan rule of thumb, sebuah model dianggap memiliki relevansi prediktif jika nilai $Q^2 > 0$. Selain itu, kekuatan prediktifnya dapat dikategorikan sebagai lemah ($Q^2 \geq 0.02$), moderat ($Q^2 \geq 0.15$), atau kuat ($Q^2 \geq 0.35$). Hasil perhitungan (Tabel 7) menunjukkan nilai Q^2 sebesar 0.620. Oleh karena nilai 0.620 ini jauh di atas 0, model ini dinyatakan 'Fit' dan memiliki relevansi prediktif. Lebih lanjut, karena

0.620 secara signifikan melampaui ambang batas 0.35, dapat disimpulkan bahwa model penelitian ini memiliki relevansi prediktif yang sangat kuat (strong predictive relevance).

INNER MODEL

Penilaian inner model (model struktural) dalam PLS-SEM bertumpu pada dua aspek, yang dilakukan pasca-validasi outer model. Aspek pertama adalah path coefficient, yang digunakan untuk menguji signifikansi statistik dari setiap jalur (hipotesis) antar konstruk. Aspek kedua adalah R-Square (R^2) dan R-Square Adjusted (R^2_{adj}), yang mengkuantifikasi kapasitas penjelasan model—yakni, proporsi varians pada variabel endogen yang dapat diatribusikan ke variabel eksogen. Nilai R^2 0.75, 0.50, dan 0.25 masing-masing merepresentasikan kekuatan model yang kuat, moderat, dan lemah.

Analisis inner model (selain R^2) bergantung pada pengujian path coefficient (koefisien jalur) untuk signifikansi dan effect size. Signifikansi jalur diuji menggunakan bootstrapping, sebuah teknik resampling yang menghasilkan t-statistic dan p-value untuk mengkonfirmasi kekuatan statistik dari hubungan tersebut (Hair et al., 2021). Secara terpisah, effect size (f^2) menilai dampak praktis dari variabel eksogen terhadap variabel endogen. Kriteria Cohen (1988) sebesar 0.02 (kecil), 0.15 (sedang), dan 0.35 (besar) digunakan untuk menginterpretasikan seberapa besar pengaruh relatif tersebut. Kedua analisis ini (signifikansi dan effect size) sangat penting untuk memahami dinamika model struktural.

1. Hasil Uji R Square

Penilaian R-Square (R^2) dan R-Square Adjusted (R^2_{adj}) sangat krusial dalam evaluasi inner model untuk mengkuantifikasi kekuatan eksplanatori (penjelasan) model. Secara spesifik, R^2 mengukur persentase varians pada variabel dependen (endogen) yang dapat diatribusikan ke variabel independen (eksogen). Tolok ukur standar digunakan untuk mengkategorikan kekuatan ini: 0.75 (kuat), 0.50 (moderat), dan 0.25 (lemah). Sementara itu, R^2_{adj} berfungsi sebagai metrik yang lebih konservatif, yang mengoreksi nilai R^2 agar tidak over-optimistic (bias) ketika model melibatkan banyak prediktor. Pada intinya, nilai R^2 dan R^2_{adj} yang tinggi menunjukkan bahwa model tersebut berhasil menjelaskan fenomena yang diteliti.

Tabel 8. Hasil R Square

Variabel Dependen	R-square	R-square adjusted
Kepercayaan Diri Mahasiswa	0.633	0.629

Sumber: Disusun oleh penulis, 2025

Berdasarkan Tabel 8, nilai R-Square (R^2) untuk variabel dependen Kepercayaan Diri Mahasiswa adalah 0.633. Ini berarti bahwa variabel-variabel independen dalam model Anda (Pengetahuan AI, Sikap terhadap Teknologi, dan Pengalaman Penggunaan AI) secara kolektif mampu menjelaskan 63.3% dari total varians (keragaman) pada variabel Kepercayaan Diri Mahasiswa. Sisa 36.7% lainnya dijelaskan oleh variabel lain di luar model penelitian ini. nilai R^2 0.75 = kuat, 0.50 = moderat, dan 0.25 = lemah, nilai 0.633 ini dapat dikategorikan memiliki kekuatan penjelasan yang Moderat (Moderate).

Nilai R-Square Adjusted adalah 0.629. Nilai ini mengoreksi nilai R-Square berdasarkan jumlah variabel independen dalam model. Fakta bahwa nilai R^2 Adjusted (0.629) sangat dekat dengan nilai R^2 (0.633) adalah hasil yang baik, yang menunjukkan bahwa nilai R-Square tidak meningkat secara artifisial (bias) akibat jumlah prediktor. Secara keseluruhan, model Anda memiliki kemampuan penjelasan yang moderat.

2. Signifikansi (Pengujian Hipotesis)

Pengujian signifikansi path coefficient (hubungan antar variabel laten) dalam inner model PLS-SEM dievaluasi menggunakan t-statistic dan p-value. Nilai-nilai ini dihasilkan melalui teknik bootstrapping (Hair et al., 2019). Karena hipotesis penelitian ini telah memiliki

arahan teoretis (bersifat positif), maka uji signifikansi yang digunakan adalah one-tailed. Berdasarkan panduan Hair et al. (2019), untuk uji one-tailed dengan $\alpha = 0.05$, sebuah jalur (path) dianggap signifikan secara statistik jika nilai t-statistic > 1.645 dan (secara ekuivalen) $p\text{-value} < 0.05$.

Tabel 9. Hasil Path Coefficients dalam Uji Signifikansi

Hipotesis	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics ((O/STDEV))	P values	Keterangan
X1_Knowledge -> Y_Self Confidence	0.126	0.129	0.047	2.697	0.004	Diterima
X2_Attitude on Tech -> Y_Self Confidence	0.336	0.336	0.066	5.046	0.000	Diterima
X3_Experience -> Y_Self Confidence	0.425	0.423	0.072	5.875	0.000	Diterima

Sumber: Disusun oleh penulis, 2025

Tahap evaluasi inner model (model struktural) dilanjutkan dengan pengujian hipotesis untuk menilai signifikansi pengaruh antar variabel. Pengujian ini didasarkan pada hasil bootstrapping (Tabel x.x), dengan kriteria penerimaan hipotesis untuk uji one-tailed adalah T-statistic > 1.645 dan P-value < 0.05 .

Hasil analisis menunjukkan bahwa ketiga hipotesis penelitian diterima:

- Hipotesis 1 (H1): Pengaruh X1_Knowledge terhadap Y_Self Confidence terbukti positif dan signifikan, dengan nilai koefisien jalur (Original Sample) sebesar 0.126, T-statistic 2.697 (yang > 1.645), dan P-value 0.004 (yang < 0.05).
- Hipotesis 2 (H2): Pengaruh X2_Attitude on Tech terhadap Y_Self Confidence terbukti positif dan signifikan, dengan koefisien jalur 0.336, T-statistic 5.046 (yang > 1.645), dan P-value 0.000 (yang < 0.05).
- Hipotesis 3 (H3): Pengaruh X3_Experience terhadap Y_Self Confidence terbukti positif dan signifikan, dengan koefisien jalur 0.425, T-statistic 5.875 (yang > 1.645), dan P-value 0.000 (yang < 0.05).

Dari ketiga hubungan tersebut, X3_Experience (0.425) menunjukkan pengaruh terkuat terhadap Kepercayaan Diri, diikuti oleh X2_Attitude on Tech (0.336), dan X1_Knowledge (0.126).

3. Effect Size

Penilaian Effect Size (f^2) sangat penting untuk memahami peran relatif setiap konstruk eksogen dalam menjelaskan sebuah konstruk endogen. Metrik ini secara spesifik mengkuantifikasi seberapa besar dampak satu prediktor terhadap nilai R^2 dari variabel dependen. Berdasarkan kriteria klasik Cohen (1988), besaran efek ini dikategorikan sebagai kecil ($f^2 = 0.02$), sedang ($f^2 = 0.15$), atau besar ($f^2 = 0.35$). Semakin tinggi nilai f^2 , semakin penting peran substantif variabel eksogen tersebut dalam model struktural.

Tabel 10. Hasil Effect Size untuk Uji Signifikansi

	X1_Knowledge	X2_Attitude on Tech	X3_Experience	Y_Self Confidence	Keterangan
X1_Knowledge	-	-	-	0.027	Efek Sedang
X2_Attitude on Tech	-	-	-	0.129	Efek Sedang
X3_Experience	-	-	-	0.195	Efek Sedang menuju Efek Kuat

Sumber: Disusun oleh penulis, 2025

Selain uji signifikansi, dilakukan pula analisis effect size (f^2) untuk menilai seberapa besar kontribusi substantif setiap variabel eksogen terhadap variabel endogen. Berdasarkan kriteria Cohen (1988), nilai f^2 0.02 dianggap kecil, 0.15 sedang, dan 0.35 besar. Hasil analisis (Tabel 10) menunjukkan bahwa X3_Experience memiliki effect size terbesar ($f^2 = 0.195$), yang diklasifikasikan sebagai efek sedang. Variabel X2_Attitude on Tech ($f^2 = 0.129$) juga menunjukkan efek sedang. Sementara itu, X1_Knowledge ($f^2 = 0.027$) menunjukkan efek kecil terhadap variabel Y_Self Confidence.

HASIL DAN PEMBAHASAN

Sebelum melangkah pada pengujian hipotesis dan pembahasan temuan, evaluasi model pengukuran (outer model) telah dilakukan secara komprehensif untuk memastikan validitas dan reliabilitas data. Hasil analisis (Tabel 2) mengkonfirmasi bahwa seluruh kriteria telah terpenuhi. Validitas konvergen terbukti baik, ditunjukkan dengan nilai Average Variance Extracted (AVE) untuk semua konstruk berada di atas ambang batas 0,50 (berkisar antara 0.591 hingga 0.712) dan nilai loading factor seluruh 21 indikator berada di atas 0,70. Demikian pula, validitas diskriminan juga terpenuhi, berdasarkan kriteria Fornell-Larcker dan cross-loading, yang menunjukkan bahwa setiap konstruk bersifat unik. Aspek reliabilitas konstruk juga terkonfirmasi sangat kuat, dengan nilai Composite Reliability (berkisar 0.852 hingga 0.925) dan Cronbach's Alpha (berkisar 0.770 hingga 0.899) untuk semua variabel melampaui ambang batas 0,70.

Evaluasi kecocokan model (model fit) juga menunjukkan kesesuaian yang sangat baik antara model dan data empiris. Meskipun parameter Chi-Square menunjukkan 'Tidak Fit' ($\chi^2=832.253$), hal ini umum terjadi dalam metodologi PLS-SEM yang sensitif terhadap jumlah sampel. Parameter fit yang lebih diandalkan dalam PLS-SEM, seperti Standardized Root Mean Square Residual (SRMR), berada pada level 0.071 (di bawah 0.10), yang didukung oleh Normed Fit Index (NFI=0.808) dan Goodness of Fit (GoF=0.657). Lebih lanjut, model ini menunjukkan kekuatan prediktif yang substansial: kemampuan eksplanatori model dikategorikan 'Moderat' ($R^2=0.633$), dan relevansi prediktif (Q^2) terbukti 'Kuat' ($Q^2=0.620$). Dengan terpenuhinya seluruh evaluasi outer model dan model fit, data ini dinyatakan valid, reliabel, dan robust untuk melanjutkan ke tahap pembahasan hipotesis.

Hasil pengujian hipotesis pertama (H1) menunjukkan bahwa Pengetahuan AI (X1) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa, sehingga hipotesis ini diterima. Temuan ini didukung oleh data statistik hasil bootstrapping yang menunjukkan koefisien jalur (Original Sample) positif sebesar 0.126, dengan nilai T-statistic 2.697 (yang melampaui nilai kritis 1.645) dan P-value 0.004 (yang lebih kecil dari $\alpha=0.05$). Temuan ini mengkonfirmasi bahwa aspek kognitif—yaitu apa yang mahasiswa "tahu" tentang AI—berfungsi sebagai fondasi penting dalam pembentukan kepercayaan diri. Pengetahuan yang memadai mengenai konsep, fungsi, dan batasan AI terbukti mampu mengurangi ambiguitas dan kecemasan teknologi (techno-anxiety), sehingga mahasiswa merasa lebih mampu mengelola tantangan yang dihadirkan oleh teknologi tersebut. Namun, penting untuk dicatat bahwa meskipun signifikan, kontribusi substantif dari Pengetahuan AI tergolong "Efek Kecil", seperti yang ditunjukkan oleh nilai effect size f^2 sebesar 0.0273. Hal ini mengindikasikan bahwa meskipun pengetahuan teoretis esensial sebagai langkah awal, dampaknya secara praktis tidak sebesar faktor afektif (sikap) atau pengalaman langsung dalam membangun kepercayaan diri mahasiswa secara komprehensif.

Hipotesis kedua (H2) yang menyatakan bahwa Sikap terhadap Teknologi (X2) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa, juga diterima. Hasil analisis bootstrapping menunjukkan koefisien jalur positif yang substansial (Original Sample = 0.336), dengan signifikansi statistik yang sangat kuat (T-statistic = 5.046; P-value = 0.000). Temuan ini menegaskan krusialnya peran komponen afektif ("merasa") dalam model penelitian. Berbeda dengan pengetahuan yang bersifat kognitif, sikap yang positif—seperti optimisme, rasa nyaman, dan memandang teknologi sebagai fasilitator alih-alih ancaman—secara langsung menumbuhkan keyakinan psikologis mahasiswa untuk beradaptasi dan berhasil. Dampak substantif dari sikap ini terkonfirmasi melalui nilai effect size (f^2) sebesar 0.129, yang dikategorikan sebagai "Efek Sedang". Hal ini menunjukkan bahwa "perasaan" (sikap) mahasiswa

terhadap teknologi memiliki dampak praktis yang jauh lebih besar dalam membentuk kepercayaan diri dibandingkan dengan "pengetahuan" (yang hanya memiliki efek kecil).

Hipotesis ketiga (H3), yang mempostulatkan bahwa Pengalaman Penggunaan (X3) berpengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa, juga diterima dengan tingkat keyakinan statistik tertinggi. Temuan ini merupakan hasil sentral dari penelitian ini, didukung oleh koefisien jalur (Original Sample) sebesar 0.425, yang merupakan nilai terkuat di antara ketiga variabel prediktor. Signifikansi hubungan ini dikonfirmasi oleh nilai T-statistic 5.875 (jauh di atas 1.645) dan P-value 0.000 (jauh di bawah 0.05). Lebih lanjut, dampak substantif dari Pengalaman (X3) juga merupakan yang terbesar, dengan nilai effect size (f^2) sebesar 0.195, yang diklasifikasikan sebagai "Efek Sedang" (menuju kuat). Temuan ini sangat selaras dengan Teori Self-Efficacy (Bandura), yang menyatakan bahwa "pengalaman penguasaan" (mastery experiences) adalah sumber pembentuk kepercayaan diri yang paling ampuh. Ini membuktikan bahwa bagi mahasiswa Bisnis dan Informatika, kepercayaan diri tidak hanya dibangun dari apa yang mereka ketahui (X1) atau rasakan (X2), tetapi secara dominan dibentuk oleh bukti empiris melalui interaksi dan praktik langsung ("melakukan") dengan teknologi AI.

Temuan penelitian ini menawarkan implikasi teoretis dan praktis yang signifikan. Secara teoretis, penelitian ini berhasil memvalidasi sebuah model anteseden integratif (kognitif, afektif, dan pengalaman) yang terbukti memiliki kekuatan prediktif moderat hingga kuat ($R^2=0.633$, $Q^2=0.620$) dalam menjelaskan Kepercayaan Diri mahasiswa di era AI. Lebih lanjut, temuan ini memperkuat Teori Self-Efficacy (Bandura) dengan menunjukkan secara empiris bahwa "pengalaman penguasaan" (Pengalaman Penggunaan, X3) adalah prediktor paling dominan ($f^2=0.195$), mengungguli komponen afektif (Sikap, $f^2=0.129$) dan kognitif (Pengetahuan, $f^2=0.027$). Secara praktis, hasil ini memberikan masukan strategis bagi Fakultas Bisnis dan Informatika Universitas Muhammadiyah Palangkaraya: upaya untuk meningkatkan kepercayaan diri mahasiswa tidak dapat hanya mengandalkan transfer pengetahuan teoretis (X1), yang terbukti memiliki dampak praktis terkecil ($f^2=0.027$). Sebaliknya, kurikulum dan intervensi pedagogis harus secara proaktif merancang ekosistem pembelajaran yang berfokus pada pengalaman praktik langsung (X3)—seperti lokakarya AI, proyek riil, dan studi kasus terapan—serta mengelola sikap positif (X2) untuk mengurangi kecemasan teknologi, guna mempersiapkan lulusan yang tidak hanya tahu, tetapi juga percaya diri dalam menghadapi disrupsi AI.

Meskipun penelitian ini telah memberikan wawasan berharga mengenai anteseden kepercayaan diri mahasiswa, terdapat beberapa keterbatasan yang perlu diakui. Pertama, penelitian ini bersifat kontekstual, karena data hanya diambil dari satu fakultas (Fakultas Bisnis dan Informatika) di satu universitas (Universitas Muhammadiyah Palangkaraya), sehingga temuan ini mungkin tidak dapat digeneralisasi secara langsung ke populasi mahasiswa yang lebih luas di institusi atau wilayah lain. Kedua, desain penelitian cross-sectional (potong lintang) hanya menangkap data pada satu titik waktu, sehingga tidak memungkinkan analisis kausalitas atau pemahaman tentang bagaimana kepercayaan diri mahasiswa berkembang seiring waktu. Ketiga, pengukuran variabel (terutama Pengetahuan dan Pengalaman) bergantung pada persepsi self-report responden, yang mungkin mengandung bias dibandingkan jika menggunakan pengukuran objektif (misalnya, tes pengetahuan atau log penggunaan). Oleh karena itu, penelitian di masa depan disarankan untuk: (a) Mereplikasi model ini di konteks institusi yang beragam; (b) Menerapkan desain studi longitudinal untuk melacak perkembangan kepercayaan diri mahasiswa dari waktu ke waktu; dan (c) Memperkaya model dengan menambahkan variabel moderator (seperti dukungan dosen) atau mediator yang relevan.

KESIMPULAN

1. Ringkasan Tujuan dan Validitas Model

Penelitian ini bertujuan untuk menguji dan menganalisis dampak dari Pengetahuan AI (X1), Sikap terhadap Teknologi (X2), dan Pengalaman Penggunaan (X3) terhadap Kepercayaan Diri (Y) mahasiswa Fakultas Bisnis dan Informatika. Sebelum penarikan kesimpulan hipotesis, serangkaian pengujian komprehensif telah mengkonfirmasi bahwa model penelitian yang diajukan adalah valid, reliabel, dan fit. Evaluasi outer model menunjukkan bahwa semua konstruk memenuhi kriteria validitas konvergen ($AVE > 0.50$) dan validitas

diskriminan (Kriteria Fornell-Larcker dan Cross Loading). Selain itu, reliabilitas konstruk terbukti sangat baik (Composite Reliability dan Cronbach's Alpha > 0.70). Evaluasi kecocokan model (model fit) juga menunjukkan kesesuaian yang kuat, dengan nilai SRMR (0.071) berada di bawah 0.10 dan nilai relevansi prediktif (Q^2) sebesar 0.620, yang mengindikasikan kekuatan prediktif model yang kuat. Dengan model yang telah terbukti robust ini, kesimpulan penelitian dapat ditarik dengan keyakinan statistik yang tinggi.

2. Jawaban atas Hipotesis 1 (H1)

Berdasarkan hasil analisis data, kesimpulan pertama adalah bahwa Hipotesis 1 (H1) diterima. Terbukti secara statistik bahwa variabel Pengetahuan AI (X1) memiliki pengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa. Temuan ini didasarkan pada nilai koefisien jalur positif (0.126), dengan nilai T-statistic sebesar 2.697 (yang > 1.645) dan P-value 0.004 (yang < 0.05). Hal ini mengindikasikan bahwa semakin tinggi tingkat pengetahuan kognitif mahasiswa mengenai AI, maka kepercayaan diri mereka juga akan meningkat. Meskipun demikian, perlu dicatat bahwa di antara ketiga variabel independen, kontribusi substantif (efek) dari Pengetahuan AI adalah yang terkecil, dengan nilai effect size (f^2) 0.027, yang diklasifikasikan sebagai efek kecil.

3. Jawaban atas Hipotesis 2 (H2)

Kesimpulan kedua adalah bahwa Hipotesis 2 (H2) diterima. Hasil analisis secara statistik membuktikan bahwa Sikap terhadap Teknologi (X2) memiliki pengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa. Temuan ini didasarkan pada koefisien jalur positif yang kuat sebesar 0.336, dengan nilai T-statistic 5.046 (jauh di atas nilai kritis 1.645) dan P-value 0.000 (jauh di bawah $\alpha = 0.05$). Hal ini mengindikasikan bahwa semakin positif sikap afektif (perasaan, optimisme, dan kenyamanan) mahasiswa terhadap teknologi baru, semakin tinggi pula tingkat kepercayaan diri mereka untuk beradaptasi dan menggunakannya. Kontribusi substantif dari Sikap (X2) ini diklasifikasikan memiliki "Efek Sedang" ($f^2 = 0.129$), yang menunjukkan dampak praktis yang lebih besar daripada Pengetahuan (X1).

4. Jawaban atas Hipotesis 3 (H3)

Kesimpulan ketiga adalah bahwa Hipotesis 3 (H3) diterima dengan tingkat signifikansi tertinggi. Hasil analisis data secara konklusif membuktikan bahwa Pengalaman Penggunaan (X3) memiliki pengaruh positif dan signifikan terhadap Kepercayaan Diri (Y) mahasiswa. Temuan ini didukung oleh koefisien jalur (Original Sample) sebesar 0.425, yang merupakan pengaruh terkuat di antara ketiga variabel independen. Signifikansi ini diperkuat oleh nilai T-statistic 5.875 (jauh di atas 1.645) dan P-value 0.000 (jauh di bawah 0.05). Hal ini menegaskan bahwa faktor perilaku ("melakukan") atau "pengalaman penguasaan" (mastery experience) adalah determinan paling dominan dalam membentuk kepercayaan diri. Semakin sering mahasiswa berinteraksi dan menggunakan alat AI secara praktis, semakin tinggi pula tingkat kepercayaan diri mereka. Kontribusi substantif dari Pengalaman (X3) juga merupakan yang terbesar, dengan nilai effect size (f^2) 0.195, yang diklasifikasikan memiliki "Efek Sedang".

5. Sintesis Temuan Utama

Secara kumulatif, penelitian ini menyimpulkan bahwa ketiga variabel independen—Pengetahuan AI, Sikap terhadap Teknologi, dan Pengalaman Penggunaan—secara simultan berkontribusi dalam menjelaskan 63.3% varians dari Kepercayaan Diri Mahasiswa ($R^2 = 0.633$). Ketiga hipotesis (H1, H2, H3) terbukti berpengaruh positif dan signifikan. Namun, sintesis temuan utama menunjukkan adanya hierarki pengaruh yang jelas. Pengalaman Penggunaan (X3) teridentifikasi sebagai prediktor paling dominan (koefisien jalur = 0.425; $f^2 = 0.195$), diikuti oleh Sikap terhadap Teknologi (X2) (koefisien jalur = 0.336; $f^2 = 0.129$), dan terakhir Pengetahuan AI (X1) (koefisien jalur = 0.126; $f^2 = 0.027$). Temuan ini secara tegas menyimpulkan bahwa untuk membangun kepercayaan diri mahasiswa Fakultas Bisnis

dan Informatika dalam menghadapi era AI, "melakukan" (pengalaman praktik) dan "merasakan" (sikap positif) memiliki dampak substantif yang jauh lebih besar daripada sekadar "mengetahui" (pengetahuan teoretis).

REFERENCES

- Afnisah, A., Muda, B., Badaruddin, & AA, N. (2025). *EXPLORING THE DETERMINANTS OF FRAUD PREVENTION IN VILLAGE FUND MANAGEMENT: EVIDENCE FROM REGENCIES AND CITIES IN NORTH SUMATRA PROVINCE, INDONESIA*. 23(11), 1941–1960.
- Chavarría-Arroyo, G., & Albanese, V. (2023). Contextualized Mathematical Problems: Perspective of Teachers about Problem Posing. *Education Sciences*, 13(1). <https://doi.org/10.3390/educsci13010006>
- Demir, S., & Uşak, M. (2025). Analyzing the Implementation of PLS-SEM in Educational Technology Research: A Review of the Past 10 Years. *SAGE Open*, 15(2), 1–23. <https://doi.org/10.1177/21582440251345950>
- García-Machado, J. J., Sroka, W., & Nowak, M. (2021). R&d and innovation collaboration between universities and business—a pls-sem model for the spanish province of Huelva. *Administrative Sciences*, 11(3). <https://doi.org/10.3390/ADMSCI11030083>
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Herce, C., Martini, C., Toro, C., Biele, E., & Salvio, M. (2024). Energy Efficiency Policies for Small and Medium-Sized Enterprises: A Review. *Sustainability (Switzerland)*, 16(3). <https://doi.org/10.3390/su16031023>
- Hilkenmeier, F., Bohndick, C., Bohndick, T., & Hilkenmeier, J. (2020). Assessing Distinctiveness in Multidimensional Instruments Without Access to Raw Data – A Manifest Fornell-Larcker Criterion. *Frontiers in Psychology*, 11(March), 1–9. <https://doi.org/10.3389/fpsyg.2020.00223>
- Janson, A. (2023). How to leverage anthropomorphism for chatbot service interfaces: The interplay of communication style and personification. *Computers in Human Behavior*, 149(August), 107954. <https://doi.org/10.1016/j.chb.2023.107954>
- Kawaguchi, M., Fukui, T., & Morinishi, K. (2021). Contribution of particle–wall distance and rotational motion of a single confined elliptical particle to the effective viscosity in pressure-driven plane poiseuille flows. *Applied Sciences (Switzerland)*, 11(15). <https://doi.org/10.3390/app11156727>
- Khan, M. K., Ammar Zahid, R. M., Saleem, A., & Sági, J. (2021). Board composition and social & environmental accountability: A dynamic model analysis of chinese firms. *Sustainability (Switzerland)*, 13(19). <https://doi.org/10.3390/su131910662>
- Kim, B. J., & Lee, J. (2024). The mental health implications of artificial intelligence adoption: the crucial role of self-efficacy. *Humanities and Social Sciences Communications*, 11(1). <https://doi.org/10.1057/s41599-024-04018-w>
- Kock, N. (2020). Using indicator correlation fit indices in PLS-SEM: Selecting the algorithm with the best fit. *Data Analysis Perspectives Journal*, 1(4), 1–4.
- Kratzer, J., Knyphausen-Aufseß, D., & Festel, G. (2021). Glancing through two decades of research on the human side of sustainable innovation: The past, the present, and directions for future research. *Sustainability (Switzerland)*, 13(11). <https://doi.org/10.3390/su13116355>
- Kusuma, F. N. P., & Rachmawati, R. (2024). Faktor yang memengaruhi intensi penggunaan mobile payment berkelanjutan di kalangan Gen Z: Ekstensi dari expectation confirmation model. *Journal of Youth and Outdoor Activities*, 1(2), 102–128. <https://doi.org/10.61511/jyoa.v1i2.2024.1390>
- Linge, A. D., Bjørkly, S. K., Jensen, C., & Hasle, B. (2021). Bandura’s Self-Efficacy Model Used to Explore Participants’ Experiences of Health, Lifestyle, and Work After Attending a Vocational Rehabilitation Program with Lifestyle Intervention – A Focus Group Study. *Journal of Multidisciplinary Healthcare*, 14(November), 3533–3548. <https://doi.org/10.2147/JMDH.S334620>
- Marzilli, E., Cerniglia, L., Cimino, S., & Tambelli, R. (2022). Internet Addiction among Young

- Adult University Students during the COVID-19 Pandemic: The Role of Peritraumatic Distress, Attachment, and Alexithymia. *International Journal of Environmental Research and Public Health*, 19(23). <https://doi.org/10.3390/ijerph192315582>
- Nasr, N. R., Tu, C. H., Werner, J., Bauer, T., Yen, C. J., & Sujo-Montes, L. (2025). Exploring the Impact of Generative AI ChatGPT on Critical Thinking in Higher Education: Passive AI-Directed Use or Human–AI Supported Collaboration? *Education Sciences*, 15(9), 1–28. <https://doi.org/10.3390/educsci15091198>
- Ocak, C., Kopcha, T. J., & Dey, R. (2023). An AI-enhanced pattern recognition approach to temporal and spatial analysis of children’s embodied interactions. *Computers and Education: Artificial Intelligence*, 5(October 2022), 100146. <https://doi.org/10.1016/j.caeai.2023.100146>
- Pereira, L. M., Sanchez Rodrigues, V., & Freires, F. G. M. (2024). Use of Partial Least Squares Structural Equation Modeling (PLS-SEM) to Improve Plastic Waste Management. *Applied Sciences (Switzerland)*, 14(2). <https://doi.org/10.3390/app14020628>
- Rasoolimanesh, S. M. (2022). Discriminant Validity Assessment in PLS-SEM: A Comprehensive Composite-Based Approach. *Data Analysis Perspectives Journal*, 3(2), 1–8.
- Salata, K. D., & Yiannakou, A. (2023). A Methodological Tool to Integrate Theoretical Concepts in Climate Change Adaptation to Spatial Planning. *Sustainability (Switzerland)*, 15(3). <https://doi.org/10.3390/su15032693>
- Saúde, S., Barros, J. P., & Almeida, I. (2024). Impacts of Generative Artificial Intelligence in Higher Education: Research Trends and Students’ Perceptions. *Social Sciences*, 13(8). <https://doi.org/10.3390/socsci13080410>
- Saulite, L., & Ščeuļovs, D. (2022). The Impact on Audience Media Brand Choice Using Media Brands Uniqueness Phenomenon. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(3). <https://doi.org/10.3390/joitmc8030128>
- Shaukat, M. M., Ashraf, F., Asif, M., Pashah, S., & Makawi, M. (2022). Environmental Impact Analysis of Oil and Gas Pipe Repair Techniques Using Life Cycle Assessment (LCA). *Sustainability (Switzerland)*, 14(15). <https://doi.org/10.3390/su14159499>
- Tambunan, W., Partiwi, S. G., & Sudiarno, A. (2024). Predictors of employee well-being: A global measurements using reflective-formative model. *Heliyon*, 10(22), e40222. <https://doi.org/10.1016/j.heliyon.2024.e40222>
- Wang, W., & Zhao, Y. (2023). Impact of Natural Disasters on Household Income and Expenditure Inequality in China. *Sustainability (Switzerland)*, 15(18). <https://doi.org/10.3390/su151813813>
- Yang, Y., Wang, M., Wang, X., Li, C., Shang, Z., & Zhao, L. (2023). A Novel Monocular Vision Technique for the Detection of Electric Transmission Tower Tilting Trend. *Applied Sciences (Switzerland)*, 13(1). <https://doi.org/10.3390/app13010407>
- Yu, W., & Chang, X. (2025). Exploration of factors of digital photo hoarding behavior among university students and the mediating role of emotional attachment and fear of missing out. *Frontiers in Psychology*, 16(September), 1–11. <https://doi.org/10.3389/fpsyg.2025.1607274>
- Zakariya, Y. F. (2022). Cronbach’s alpha in mathematics education research: Its appropriateness, overuse, and alternatives in estimating scale reliability. *Frontiers in Psychology*, 13(December), 1–6. <https://doi.org/10.3389/fpsyg.2022.1074430>
- Zhou, F., & Liu, Y. (2022). Blockchain-Enabled Cross-Border E-Commerce Supply Chain Management: A Bibliometric Systematic Review. *Sustainability (Switzerland)*, 14(23). <https://doi.org/10.3390/su142315918>